



# PSC 2007

98-F-REN-186

## پیش بینی کوتاه مدت باد با استفاده از شبکه های عصبی چندلایه آموزش یافته با الگوریتم PSO جهت کاربردهای توربین بادی

غلامحسین ریاحی  
دهکردی

علی کاشفی کاویانی

علی جهانبانی  
اردکانی

سیدعلی پورموسوی  
کانی

قطب علمی قدرت، دانشکده مهندسی برق دانشگاه صنعتی امیرکبیر  
تهران

### واژه های کلیدی: پیش بینی باد، شبکه های عصبی چندلایه، الگوریتم بهینه سازی PSO

#### چکیده:

دانست. از آنجا که پیش بینی باد توسط شبکه عصبی تابعی پیچیده و غیرخطی است، لذا استفاده از روش های بهینه سازی در فرآیند آموزش شبکه های عصبی مورد توجه قرار می گیرد. داده های باد از منطقه ای در کشور دانمارک و با فرکانس ۲/۵ ثانیه نمونه برداری شده است. پیش بینی برای داده های باد واقعی و باد فیلتر شده صورت می گیرد. کار اصلی مقاله، استفاده از الگوریتم تکاملی PSO در آموزش شبکه عصبی و ارائه توجیهی برای استفاده از داده های فیلتر شده در پیش بینی باد می باشد.

#### ۱- مقدمه

تغییرات سرعت باد را در فواصل زمانی مختلف لحظه ای، دقیقه ای، ساعتی، روزانه، هفتگی، فصلی و سالانه می توان بررسی کرد. در برنامه ریزی نصب توربین های بادی پیش بینی باد سالانه باید مدنظر قرار گیرد [۱]. در حالی که

این مقاله پیش بینی بسیار کوتاه مدت باد را جهت کاربردهای توربین بادی ارائه می دهد. با توجه به گسترش روزافزون استفاده از انرژی بادی در تولید جهانی انرژی و با توجه به ساختار نامطمئن و گسسته تولید انرژی بادی، پیش بینی در فواصل زمانی مختلف ضرورت می یابد. در این مطالعه، از شبکه های عصبی آموزش یافته با الگوریتم تکاملی PSO جهت پیش بینی باد استفاده شده است. ساختار تغییرپذیر و معمولاً غیرمتناوب باد باعث می شود تا الگوریتم های آموزشی معمول جهت آموزش شبکه های عصبی که از روش های گرادینتی جهت آموزش استفاده می کنند، به خوبی نتوانند فرآیند آموزش را کامل کنند. از طرفی هدف از آموزش شبکه های عصبی یافتن اندازه وزن ها و بایاس ها به نحوی است که خطای داده های آموزش را به حداقل برساند. لذا آموزش شبکه های عصبی را می توان در بردارنده یک مسئله بهینه سازی

پیش‌بینی‌ها برای هر روز انجام گرفته است. در [۸] از دو روش ARIMA و شبکه‌های عصبی برای پیش‌بینی استفاده شده و مقایسه‌ای صورت گرفته است.

در این مقاله از شبکه عصبی چند لایه جهت پیش‌بینی کوتاه‌مدت (یک گام جلوتر- ۲/۵ ثانیه) باد فیلتر شده و فیلتر نشده استفاده می‌شود. شبکه ساخته شده با استفاده از الگوریتم تکاملی PSO آموزش داده می‌شود. نتایج حاصل از شبکه آموزش یافته نشان می‌دهد که خطای پیش‌بینی شبکه پیشنهادی نسبت به روش آموزشی پس‌انتشار<sup>۲</sup> کمتر می‌باشد.

در بخش دوم این مقاله به بررسی اجمالی اهمیت پیش‌بینی کوتاه‌مدت باد پرداخته می‌شود. سپس در بخش سوم به شبکه‌های عصبی چندلایه پرداخته می‌شود. بخش چهارم اختصاص به معرفی الگوریتم تکاملی PSO دارد. در بخش پنجم به چگونگی به کارگیری الگوریتم PSO در آموزش شبکه عصبی پرداخته می‌شود. بخش ششم شامل اعمال الگوریتم پیشنهادی روی داده‌های باد و مقایسه نتایج آن با نتایج حاصل از شبکه عصبی آموزش یافته با الگوریتم پس انتشار می‌شود.

## ۲- اهمیت پیش‌بینی کوتاه‌مدت باد

تولید انرژی از طریق توربین‌های بادی بیشترین رشد را در میان بخش‌های مختلف تولید انرژی در جهان با رشد ۲۵۰ درصد طی سال‌های ۲۰۰۰ تا ۲۰۰۴ به خود اختصاص داده است [۶]. طی سالیان اخیر بسیاری از کشورها به اهمیت انرژی پاک و ارزان باد در تولید انرژی مورد نیازشان پی برده و برنامه‌های بلند مدت و بودجه‌های کلانی را برای توسعه علمی و صنعتی در این بخش اختصاص داده‌اند. در نتیجه سهم تولید انرژی باد در کل الکتریسیته تولیدی در حال رشد است. اما همانطور که می‌دانیم، باد منبع انرژی پیوسته نیست. یعنی منابع ثابت تولید توان نیستند و با تغییرات سرعت باد، میزان انرژی تولیدی آنها نیز تغییر کرده و باعث نوسانات کنترل نشده در ولتاژ و فرکانس تولیدی می‌شوند. همچنین توربین‌های بادی دارای حد بالا و پایین سرعت هستند و چنانچه سرعت باد از

سیستم کنترل توربین بادی نیازمند پیش‌بینی در بازه‌های زمانی چند ثانیه‌ای می‌باشد چرا که مسئله اصلی در کنترل توربین‌های بادی، تاخیرهای مرتبط با سیستم توربین بادی است. این تاخیرها بر روی پاسخ زمانی سیستم کنترل تاثیرگذار است. پیش‌بینی کوتاه‌مدت سرعت باد می‌تواند برای کنترل دینامیکی یک توربین بادی استفاده شود زیرا تصمیم‌گیری‌های کوتاه مدت در کنترل توربین بادی، حفاظت آن و همچنین استحصال حداکثر توان باد بسیار مهم است. این تصمیم‌گیری‌ها می‌تواند شامل اتصال یا قطع یک بار، تغییر زاویه گام<sup>۱</sup> پره‌های توربین بادی و یا هر عمل کنترلی دیگر که خود شامل تاخیر زمانی می‌شوند، باشد [۱].

مقاله‌های متعددی در زمینه پیش‌بینی کوتاه مدت باد ارائه شده‌اند. در [۲] پیش‌بینی باد متوسط برای گام‌های زمانی ۱۰ دقیقه و یک ساعت با به کارگیری شبکه‌های عصبی انجام گرفته شده است. ورودی‌های شبکه عصبی شامل اطلاعات سرعت باد و جهت تغییرات آن است. در [۳] پیش‌بینی کوتاه‌مدت حداکثر مقدار باد براساس اندازه‌گیری‌های پیوسته در محل ریل قطار هوایی انجام می‌گیرد. مدل ارائه شده براساس اطلاعات سرعت باد و سایر اطلاعات هواشناسی که با فرکانس زیادی نمونه‌برداری می‌شود کار می‌کند. در [۴] روشی جدید جهت دسترسی هم‌زمان به میزان ریسک پیش‌بینی انجام شده ارائه شده است. در این روش ابتدا فاصله اطمینان پیش‌بینی از روی مقدار مشخص شده توسط کاربر محاسبه شده و در مرحله دوم دو اندیس محاسبه می‌شوند که ریسک جوی پیش‌بینی را با استفاده از اندازه‌گیری طیف چندسناریوی پیش‌بینی عددی و توان تولیدی آن نشان می‌دهند. در [۵] از یک سیستم استنتاجی عصبی-فازی برای پیش‌بینی بسیار کوتاه‌مدت باد استفاده شده است. در [۶] تکنیک‌های مختلف پیش‌بینی باد جهت تخمین میزان انرژی تولیدی توربین بادی مورد بررسی قرار گرفته است. در [۷] برای پیش‌بینی باد از داده‌های جمع آوری شده از چند منطقه با فواصل مشخص استفاده شده است و برای یافتن ضرایب وزنی مربوط به هر یک در پیش‌بینی نهایی از شبکه عصبی استفاده شده است. این


<sup>2</sup> Back Propagation

<sup>1</sup> pitch

## ۳- شبکه‌های عصبی چندلایه

مفهوم پرسپترون در سال ۱۹۴۳ توسط McCulloch و Pitts به عنوان یک نورون مصنوعی ارائه شد. در شکل (۱) یک پرسپترون با ورودی بایاس نشان داده شده است

شکل (۱): یک پرسپترون با ورودی بایاس



شبکه عصبی پرسپترون چندلایه نشان‌دهنده یک ارتباط غیر خطی بین بردار ورودی‌ها و بردار خروجی‌ها می‌باشد. این کار از طریق اتصال نرون‌های هر گره در لایه‌های قبلی و بعدی انجام می‌شود [۹]. خروجی نرون‌ها در ضرایب وزنی ضرب می‌شود و به تابع غیر خطی فعال‌سازی به عنوان ورودی داده می‌شود. در مرحله آموزش، به پرسپترون اطلاعات آموزش داده می‌شود. سپس وزن‌های شبکه به گونه‌ای تنظیم می‌شوند که خطای بین خروجی پیش‌بینی شده و هدف کمینه گردد و یا اینکه تعداد دفعات آموزش به مقدار حداکثر از پیش تعیین شده برسد. سپس به منظور سنجش صحت آموزش انجام شده، یک سری ورودیهای تجربه نشده به شبکه اعمال می‌شود. این ورودیها، باید متفاوت از ورودیهای بکار گرفته شده برای آموزش شبکه باشند. عموماً آموزش شبکه‌های عصبی بسیار پیچیده و یک مسأله بهینه‌سازی با تعداد متغیر زیاد است.

در این مطالعه از شبکه عصبی با یک لایه ورودی، یک لایه پنهان و یک لایه خروجی استفاده شده است. تعداد نورونها در لایه ورودی برابر ۳، در لایه پنهان برابر ۴ و در لایه خروجی برابر ۱ می‌باشند.

## ۴- الگوریتم اجتماع ذرات

الگوریتم اجتماع ذرات یک الگوریتم بهینه‌سازی تقلیدی از رفتارهای جوامع جانوری در پردازش دانش جامعه است. این الگوریتم از دو زمینه ریشه گرفته است. نخست

محدوده مجاز تجاوز کند، توربین بادی توسط کنترلر خاموش خواهد شد که خروج یک واحد تولید بزرگ شوک سنگینی به کل شبکه سراسری می‌باشد [۲]. می‌توان گفت که افزایش ضریب نفوذ انرژی بادی هنگامی ممکن است که مواردی همچون کنترل توربین بادی، تولید بهینه میان واحدها، محدودیت‌های رزرو و توزیع توان تولیدی میان واحدهای نیروگاهی مد نظر قرار گرفته شده باشد.

پیش‌بینی توان تولیدی باد امکان مدیریت بار بهینه سیستم و بهره‌برداری بهینه از شبکه را ممکن می‌سازد. همچنین در مزارع بادی امکان تولید بهینه و تعمیر و نگهداری توربین‌ها را میسر می‌سازد. همچنین پیش‌بینی کوتاه‌مدت را می‌توان برای کنترل توربین‌ها و حفاظت از آنها در مقابل بادهای ناگهانی بزرگ به کار گرفت. از طرفی می‌توان گفت که پیش‌بینی کوتاه‌مدت در شبکه‌های تجدیدساختار شده هم برای اپراتورهای شبکه و هم برای تولید کنندگان مسئله‌ای بسیار مهم تلقی می‌گردد که امکان بهره‌برداری بهینه از کل واحدهای شبکه و امکان خرید و فروش بار را میسر می‌سازد.

همانطور که می‌دانیم، باد در بازه‌های زمانی کوتاه‌مدت دارای نوسانات زیادی است، به طوری که طیف سیگنالی باد دارای مولفه‌های فرکانسی بی‌تاثیری است که فیلتر کردن آنها باعث پیش‌بینی دقیق‌تر باد خواهد شد [۱]. فیلتر کردن داده‌های سرعت باد بخش‌های نامطلوب طیف فرکانسی سرعت باد اندازه‌گیری شده را که در کاربردهای واقعی اثر بسیار کمی دارند، حذف می‌کند. به این ترتیب، سرعت باد موثر باقیمانده، سرعت باد بعد از فیلتر شدن در پره‌های روتور می‌باشد. میزان فیلتر شدن باد بستگی به سطح مقطع روتور دارد [۱]. در این موارد بیشتر از یک فیلتر پایین‌گذر استفاده می‌شود که توسط سیستم مکانیکی توربین بادی به کل سیستم اعمال می‌گردد. فیلتر کردن داده‌های سرعت باد باعث هموار شدن شکل موج شده و کار پیش‌بینی آسان‌تر می‌گردد.

در این مطالعه مسئله پیش‌بینی کوتاه‌مدت برای هر دو داده فیلتر شده و فیلتر نشده سرعت باد مورد توجه قرار می‌گیرد.

بیست و دومین کنفرانس بین‌المللی برق

از طرفی اگر چه الگوریتم PSO قادر است ناحیه جواب بهینه را بسیار سریع پیدا کند، ولی با رسیدن به این ناحیه، سرعت همگرایی آن به شدت کاهش می‌یابد. برای رفع این مشکل، رابطه (۴) به صورت زیر تصحیح می‌گردد.

$$V_i(t+1) = \omega V_i(t) + c_1 r_1 (P_i(t) - X_i(t)) + c_2 r_2 (P_g(t) - X_i(t))$$

در معادله بالا داریم:

$\omega$ : وزن اینرسی است.

$c_1$ : پارامتری مثبت به نام پارامتر شناختی است.

$c_2$ : پارامتری مثبت به نام پارامتر اجتماعی است.

استفاده از پارامتر وزن اینرسی باعث می‌شود که مصالحه‌های بین توانایی اکتشاف سراسری و محلی دسته ایجاد گردد. وزن اینرسی بزرگ، محرکی برای بزرگتر شدن مقدار بردار سرعت ذرات در سراسر ناحیه جوابها (حرکت به سمت مناطقی از فضای جستجوی جواب مسئله که پیشتر تجربه نشده‌اند) بوده، در حالیکه یک وزن اینرسی کمتر سبب کوچک شدن فضای جواب مسئله در ناحیه کوچک فعلی می‌شود. در واقع وزن کمتر باعث می‌شود که جستجو در مناطقی که در گذشته تجربه شده‌اند، با دقت بیشتری ادامه پیدا نماید. انتخاب اندازه مناسب برای  $\omega$ ، متضمن برقراری تعادل مطلوب بین توانایی اکتشاف در فضای جوابهای محلی و سراسری بوده و در نتیجه باعث افزایش کارایی الگوریتم می‌گردد. نتایج تجربی نشان می‌دهند که انتخاب مقادیر بزرگ برای  $\omega$  در آغاز جستجو، باعث می‌شود که اولویت اکتشافات سراسری نسبت به اکتشافات محلی بالاتر رود، و با کاهش تدریجی  $\omega$  جستجو در فضاهای محلی با دقت بیشتری دنبال گردد. در نتیجه مقدار  $\omega$  در ابتدای جستجو برابر ۱ انتخاب می‌گردد و تدریجاً به صفر میل می‌کند [۱۱].

با توجه به قابلیت الگوریتم PSO در یافتن جواب بهینه سراسری با احتمال بسیار بالا و نرخ همگرایی بالا، از این الگوریتم برای آموزش شبکه‌های عصبی استفاده شده است.

زندگی مصنوعی (مانند دسته پرندگان، ماهی‌ها) و دوم محاسبات تکاملی [۱۰]. مبنای توسعه الگوریتم PSO این است که، جواب‌های ممکن در یک مسأله بهینه‌سازی به صورت پرندگانی بدون حجم و خصوصیات کیفی در نظر گرفته می‌شوند که از آنان به عنوان ذرات یاد می‌شود، این پرندگان در یک فضای  $n$ -بعدی پرواز کرده و مسیر حرکت خود در فضای جستجو را بر اساس تجارب گذشته خود و همسایگان نشان تغییر می‌دهند.

در دسته‌ای متشکل از  $N$  جزء، موقعیت جزء  $i$ ام تحت اثر یک بردار مکانی  $n$ -بعدی مطابق معادله (۱) قرار دارد.

$$X_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in S \quad (1)$$

که در آن  $S$  فضای جستجو است. این جزء همچنین دارای یک بردار سرعت به صورت معادله (۲) می‌باشد.

$$V_i = [v_{i1}, v_{i2}, \dots, v_{in}]^T \in S \quad (2)$$

بهترین موقعیت قبلی بدست آمده برای جزء  $i$ ام، با استفاده از معادله (۳) نمایش داده می‌شود.

$$P_i = [p_{i1}, p_{i2}, \dots, p_{in}]^T \quad (3)$$

در نهایت موقعیت جدید اجزای دسته با استفاده از معادلات (۴) و (۵) به دست می‌آید.

$$V_i(t+1) = V_i(t) + c_1 r_1 (P_i(t) - X_i(t)) + c_2 r_2 (P_g(t) - X_i(t)) \quad (4)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (5)$$

در این معادلات:

$g$ : اندیس به کار رفته برای ذره‌ای است که بهترین موقعیت را دارد.

$t$ : نمایانگر تعداد تکرار می‌باشد.

$c$ : ثابت شتاب، که میزان وابستگی ذرات به کل گروه و خود ذره را مشخص می‌کند.

$r_1$  و  $r_2$ : اعدادی تصادفی در بازه  $[0, 1]$  می‌باشد.

سرعت هر یک از ذرات دارای مقدار حداکثری است که توسط کاربر تعیین می‌شود. این عامل باعث می‌شود که اندازه سرعت دسته کنترل شود و از افزایش فضای جوابهای مسئله به نواحی که در آن جواب وجود ندارد، جلوگیری شود.

## ۵- بکارگیری PSO در آموزش شبکه های عصبی

متغیرهای بهینه سازی در آموزش یک شبکه عصبی شامل وزن ها و بایاس های مربوط به شبکه می شود. اگر لایه  $m$  از یک شبکه فرضی متشکل از  $R$  ورودی و  $M$  نرون باشد، آنگاه ماتریس وزن ها ( $W_n$ ) و بایاس های ( $B_n$ ) این لایه را می توان با رابطه (۷) بصورت زیر نمایش داد:

$$W^n = [w_1^n, w_2^n, \dots, w_M^n]^T \quad (7)$$

$$B^n = [b_1^n, b_2^n, \dots, b_M^n]^T$$

که در آن،  $w_m^n = [w_{m,1}^n, w_{m,2}^n, \dots, w_{m,R}^n]^T$  بردار وزنهایی است که نرون  $m$  از لایه  $m$  را به ورودیهای همان لایه مربوط می کند. بردار پارامترهای این لایه را نیز می توان با رابطه (۸) نشان داد:

$$X^n = [w_1^n \dots w_M^n; b_1^n \dots b_M^n]^T \quad (8)$$

به همین ترتیب، به ازای هر لایه، ماتریس های وزن و بایاس و بردار پارامترهای مربوطه تعریف می شود. با زیر هم قرار دادن بردار پارامترهای همه لایه های شبکه، بردار متغیرهای بهینه سازی مورد نظر تشکیل می شود. نهایتاً برای یک شبکه  $L$  لایه بردار متغیرهای  $X$  را می توان از رابطه (۹) بدست آورد:

$$X = [X^1, X^2, \dots, X^L]^T \quad (9)$$

در واقع این بردار همان بردار موقعیت ذکر شده در رابطه (۱) است که مقدار بهینه آرگومانهای آن با استفاده از الگوریتم PSO محاسبه خواهد شد.

روند کار بدین ترتیب است که ابتدا  $N$  بردار موقعیت  $X_i$  ( $i=1, 2, \dots, N$ )، که  $N$  برابر با تعداد اعضای دسته می باشد، بصورت تصادفی تولید می گردد. جمعیت دسته نیز معمولاً ۴ تا ۵ برابر تعداد متغیرهای بهینه سازی انتخاب می شود. شبکه عصبی به ازای پارامترهایی برابر با متغیرهای این بردارها اجرا شده و خطای بدست آمده از هر اجرا به عنوان میزان برازندگی بردار متغیرهای آن شبکه در نظر گرفته می شود. خطاهای به دست آمده از تمامی ذرات می باشد. در این مرحله بردارهای  $P_i$  و  $P_g$  با توجه به برازندگیهای بدست آمده محاسبه گردیده، و  $N$  بردار موقعیت جدید با استفاده از روابط


(۵) و (۶) تولید می شود. این روند آنقدر تکرار می شود تا همگرایی نهایی حاصل گردد. منظور از همگرایی نهایی رسیدن به بردار موقعیت بهینه، به نحوی است که خطای آموزش به ازای آن کمینه گردد. در اجرای الگوریتم PSO، ضرایب  $C_1$  و  $C_2$  برابر با ۲ انتخاب شده [۱۰] و ضریب اینرسی ( $\omega$ ) نیز در ابتدا برابر با ۱ در نظر گرفته شده که در طول تکرارها تدریجاً به سمت صفر میل می کند.

## ۶- شبیه سازی و مقایسه نتایج

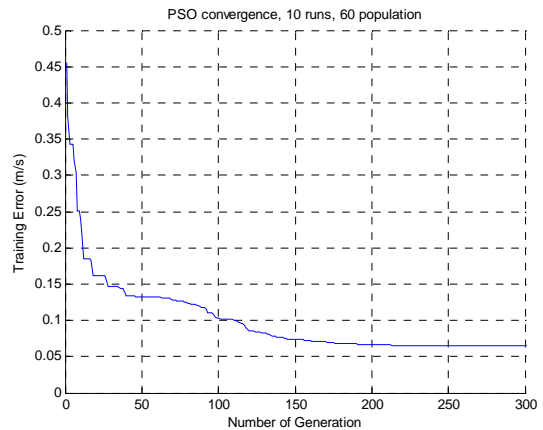
در این بخش از داده های باد متعلق به یک منطقه در کشور دانمارک که با فرکانس ۲/۵ ثانیه نمونه برداری شده است، برای بررسی نتایج حاصل از الگوریتم پیشنهادی استفاده می شود. از ۱۰۰۰ داده سرعت باد در دو دسته ۵۰۰ تایی برای آموزش و تست دو شبکه عصبی مختلف استفاده شده است. این داده ها فیلتر نشده و واقعی هستند. ورودی هر شبکه شامل ۱۰ داده سرعت باد از گذشته بوده و هدف از آموزش شبکه، پیش بینی یک گام زمانی جلوتر یعنی ۲/۵ ثانیه بعد است. این مسئله برای هر دو الگوریتم آموزشی در نظر گرفته شده است. شکل (۲) روند آموزش شبکه عصبی را با الگوریتم پیشنهادی و برای داده های ذکر شده نشان می دهد. نتیجه پیش بینی الگوریتم پیشنهادی و مقایسه آن با داده های واقعی در شکل (۳) دیده می شود. MAPE میانگین اندازه درصد خطا در ۵۰۰ پیش بینی یک گام جلوتر انجام گرفته شده می باشد.

همچنین جدول (۱) چهار خطای محاسبه شده برای دو الگوریتم آموزشی پس انتشار و PSO را نشان می دهد. همانطور که دیده می شود، خطاهای حاصل از الگوریتم پیشنهادی مقاله در هر چهار مورد کمتر از الگوریتم آموزشی PSO بوده است.

بیست و دومین کنفرانس بین المللی برق



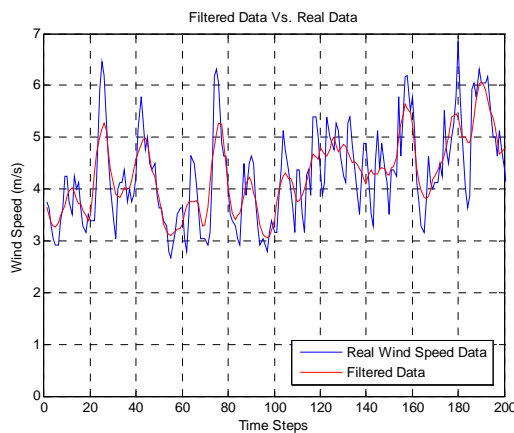
شکل (۳): باد پیش بینی شده و مقادیر واقعی آن.



شکل (۲): روند آموزش در الگوریتم PSO.

MaxAPE (%)	MAPE	Maximum Error	Mean Error	
۲۹/۴۸۹۹	۳/۵۲۴۶۲	۱/۲۰۷۳۴	۰/۱۴۶۶۷۵	الگوریتم پس انتشار
۱۹/۵۶۰۵	۳/۴۲۵۷۷	۰/۹۵۸۰۵۹	۰/۱۴۵۲۴۷	الگوریتم PSO


جدول (۱): مقایسه خطاهای حاصل از دو روش آموزشی شبکه عصبی.



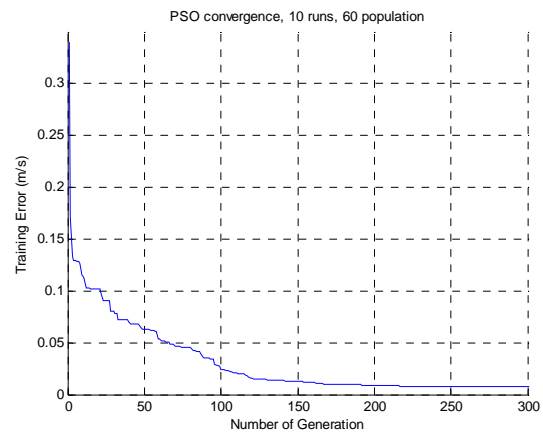
شکل (۴): بخشی از داده های باد فیلتر شده و مقایسه با مقادیر واقعی آن.

در ادامه الگوریتم پیشنهادی با استفاده از داده های فیلتر شده باد مورد بررسی و مقایسه قرار گرفته است. فرکانس فیلتر پایین گذرطبق مرجع [۱] برابر  $0.07$  هرتز در نظر گرفته شده است که با توجه به پاسخ فرکانسی توربین بادی به دست آمده است. در نتیجه یک توربین بادی خاص که در مرجع [۱] نام برده شده، سیگنال های با فرکانس بیشتر از  $0.07$  هرتز را حذف می کند. این پدیده در اثر خواص مکانیکی توربین بادی است. با توجه به فرکانس قطع فیلتر مورد نظر، برای فیلتر کردن داده ها از داده های ۳ گام قبل و ۳ گام بعد، میانگین (دوره  $15 = 0.07 \times 1$  ثانیه) گرفته شده است. در شکل (۴) بخشی از داده های فیلتر شده و داده های واقعی که برای تست سیستم استفاده شده اند، نشان داده شده است.

با استفاده از داده های فیلتر شده، شبکه عصبی پیشنهادی اجرا شده که در شکل (۵) روند آموزش شبکه با الگوریتم PSO دیده می شود. همچنین شکل (۶) داده های فیلتر شده واقعی و مقادیر پیش بینی شده آن را توسط الگوریتم پیشنهادی مقاله نشان می دهد. تمامی پیش بینی برای یک گام زمانی جلوتر (۲/۵ ثانیه) می باشد.



شکل (۶): باد پیش بینی شده و مقادیر واقعی آن.



شکل (۵): روند آموزش در الگوریتم PSO با داده های فیلتر شده.

جدول (۲) هم شامل ۴ خطای محاسبه شده برای دو الگوریتم آموزشی به کار گرفته شده می باشد. همانطور که دیده می شود، خطای پیش بینی در هر دو روش از داده های فیلتر نشده بسیار بهتر است که مسئله ای کاملاً محرز می باشد.

MaxAPE (%)	MAPE	Maximum Error	Mean Error	
۶/۹۶۸۴۶	۱/۳۲۲۳۶	۰/۲۶۶۲۷۴	۰/۰۵۴۷۴۵۴	الگوریتم پس انتشار
۴/۱۶۲۸۲	۰/۵۷۲۴۸۷	۰/۱۶۲۵۳۳	۰/۰۲۳۹۴۷۱	الگوریتم PSO

جدول (۲): مقایسه خطاهای حاصل از دو روش آموزشی شبکه عصبی برای داده های فیلتر شده.

آموزشی پس انتشار دارد که به طور معمول در پیش بینی باد کوتاه مدت با شبکه های عصبی مورد استفاده قرار می گیرد.

## ۷- نتیجه گیری

با افزایش ضریب نفوذ انرژی بادی، مواردی همچون کنترل توربین بادی، تولید بهینه میان واحدها، محدودیت های رزرو و توزیع توان تولیدی میان واحدهای نیروگاهی مد نظر قرار می گیرد. در نتیجه اهمیت پیش بینی باد به عنوان منبع گسسته تولید انرژی خود را نشان می دهد. از طرفی توربین های بادی به خاطر لختی های مکانیکی همانند فیلتر پایین گذر عمل کرده و بخشی از داده های واقعی باد را فیلتر می کنند. در این مقاله نشان داده شد که پیش بینی باد در کوتاه مدت توسط شبکه عصبی آموزش یافته با PSO در هر دو حالت باد فیلتر شده و فیلتر نشده جواب های بهتری نسبت به الگوریتم

## ۸- مراجع

- [۱] G.H. Riahy, M.Abedi, "Short term wind speed forecasting for wind turbine applications using linear prediction method", Renewable Energy, 2007.
- [۲] M.C. Alexiadis, P. S. Dokopoulos, H. S. Sahsamanoglou, "Short-term forecasting of wind speed and related electrical power", Solar Energy Vol. 63, No 1, pp 61-68, 1998.
- [۳] U.Hoppmann, S. Keonig, T. Tielkes, G. Matschke, "A short-term strong wind prediction model for railway application: design and verification", Wind Eng & Industrial aerodynamics, 2002, 1127-1134.

[۴] G. N. Kariniotakis, P. Pinson, "Uncertainty of short-term wind power forecasts- A methodology for on-line assessment.", IEEE conference on probabilistic methods applied to power systems, Iowa State University, September 12-16, 2004.

[۵] C. W. Potter, M. N. Negnevitsky, "Very short-term wind forecasting for Tasmanian power generation.", IEEE Transaction on power systems, Vol. 21, NO. 2, MAY 2006.

[۶] M. N. Negnevitsky, C. W. Potter, Innovative short-term wind generation prediction techniques.", PSCE, IEEE 2006.

[۷] Ahmet Oztopal, "Artificial neural network approach to spatial estimation of wind velocity data.", Energy Conversion and Management (2006) 395-406.

[۸] E. Cadenas, W. Rivera, "Wind speed forecasting in the south coast of Oaxaca, Mexico.", Renewable Energy 32 (2007) 2116-2128.

[۹]: Rumelhart, D.E., Hinton, E., Williams, J., 1986. Learning internal representation by error propagation. Parallel Distributed Processing 1, 318-362.

[۱۰]: Clerc, M., Kennedy, J., 2002. The particle swarm-explosion, stability, and convergence in a multidimensional complex space. IEEE Transactions on Evolutionary Computation 6 (1), 58-73.

[۱۱]: Konstantinos E. Parsopoulos and Michael N. Vrahatis, "On the Computation of All Global Minimizers Through Particle Swarm Optimization", IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION, VOL. 8, NO. 3, JUNE 2004.